

中文引用格式:刘迪,杨辉,卢才武,等. 基于 MISSA-CNN-BiLSTM 模型的尾矿坝位移预测[J]. 中国安全科学学报, 2024, 34(9): 145-154.

英文引用格式:LIU Di, YANG Hui, LU Caiwu, et al. Prediction of displacement of tailings dams based on MISSA-CNN-BiLSTM model [J]. China Safety Science Journal, 2024, 34(9): 145-154.

基于 MISSA-CNN-BiLSTM 模型的尾矿坝位移预测*

刘迪^{1,2}, 杨辉^{1,2}, 卢才武^{1,2}教授, 阮顺领^{1,2}教授, 江松^{1,2}教授

(1 西安建筑科技大学 资源工程学院, 陕西 西安 710005;

2 西安建筑科技大学 西安市智慧工业感知计算与决策重点实验室, 陕西 西安 710005)

中图分类号: X936

文献标志码: A

DOI: 10.16265/j.cnki.issn1003-3033.2024.09.1091

基金项目: 国家自然科学基金资助(51208282); 陕西省社会科学基金资助(2023R035)。

【摘要】 为应对尾矿坝位移预测所面临的复杂情况和精度要求, 提出一种基于多算法耦合的尾矿坝位移动态预测模型。首先, 基于时间序列分解模型将累计位移分为趋势项和周期项, 利用高斯回归时间序列预测模型预测趋势项位移; 然后, 运用不同 Copula 函数研究诱发因素与周期项位移的整体相关性, 鉴于周期项位移影响因素多样性与强非线性的特点, 采用多策略融合的改进麻雀搜索算法改进麻雀搜索算法(MISSA)-卷积神经网络(CNN)-双向长短期记忆(BiLSTM)模型预测周期项位移; 最后, 将高斯回归趋势项位移预测值和 MISSA-CNN-BiLSTM 周期项位移预测值叠加。结果表明: 尾矿坝累积位移预测值与实测值基本一致, 预测结果相关性系数 R 为 0.996, 均方根误差(RMSE)为 0.13 mm, 建立的 MISSA-CNN-BiLSTM 多算法耦合模型预测精度较高, 且能较好地预测尾矿坝位移的阶跃型变化。

【关键词】 改进麻雀搜索算法(MISSA); 卷积神经网络(CNN); 双向长短期记忆(BiLSTM); 尾矿坝; 位移预测; 深度学习模型

Prediction of displacement of tailings dams based on MISSA-CNN-BiLSTM model

LIU Di^{1,2}, YANG Hui^{1,2}, LU Caiwu^{1,2}, RUAN Shunling^{1,2}, JIANG Song^{1,2}

(1 School of Resource Engineering, Xi'an University of Architecture and Technology, Xi'an Shaanxi 710055, China; 2 Xi'an Key Laboratory of Perceptive Computing and Decision for Intelligent Industry, Xi'an University of Architecture and Technology, Xi'an Shaanxi 710055, China)

Abstract: A comprehensive and sophisticated multi-algorithm coupled dynamic prediction model is proposed to address the intricate reality and stringent accuracy requirements of predicting tailings dam displacement. Firstly, by employing a time series decomposition model, the cumulative displacement is disaggregated into its trend and cyclical components. The trend term displacement is then forecasted using a Gaussian regression time series prediction model. Secondly, various Copula functions are employed to investigate the overall correlation between the inducing factors and the cyclical term displacement. Owing to the diverse influencing factors and strong nonlinearities associated with the cyclical term displacement,

the MISSA-CNN-BiLSTM model is utilized for prediction. Lastly, the predicted trend term displacement from the Gaussian regression model and the predicted cyclical term displacement from the MISSA-CNN-BiLSTM model are merged. The results demonstrate a high degree of consistency between the predicted cumulative landslide displacements and the measured values, with a correlation coefficient of 0.996 and a root mean square error (RMSE) of 0.13 mm. The multi-algorithm coupled model, based on MISSA-CNN-BiLSTM, exhibits remarkable prediction accuracy and effectively captures step changes in tailings dam displacements.

Keywords: multi strategy improved sparrow search algorithm(MISSA); convolutional neural networks (CNN); Bi-directional long short-term memory (BiLSTM); tailing dam; displacement prediction; deep learning model

0 引言

位移预测作为灾害预报的有效手段,对降低灾害损失具有重要意义^[1]。然而,现有位移预测模型常用于传统边坡,对尾矿坝的预测精度和适用性有限。尾矿坝由特殊的三相非饱和土构成,其土体结构中液态体积较一般土体多,水-土特征曲线与一般非饱和土有较大差别^[2],使得尾矿坝在水分运移过程发生的土体饱和度、变形及渗透性变化更为明显;传统边坡位移主要是由水库的外部动、静水压力^[3]作用产生,而尾矿坝位移变化主要通过水库对尾矿坝的渗透作用^[4]改变其内部应力,从而增强尾矿坝形变能力。这些差异增加了尾矿坝位移影响机制的复杂性及位移预测的难度。

针对尾矿坝位移预测所面临的复杂情况和精度要求,单一预测模型往往难以满足需求。因此,综合多种模型优势以提高预测精度至关重要。王晨辉等^[5]利用集合经验模态分解算法分解累计位移序列并挖掘位移变形局部特征,并结合支持向量回归法(Support Vector Regression, SVR)实现了滑坡位移预测;高雅萍等^[6]使用经验模态分解算法分解位移并结合灰色预测模型(Grey Model, GM)预测位移;张振坤等^[7]提出结合多头注意力机制与长短期记忆(Long Short-Term Memory, LSTM)网络的位移预测模型,并预测滑坡位移;唐菲菲等^[8]提出结合注意力机制的双向LSTM(Bi-directional LSTM, BiLSTM)模型,并预测了滑坡位移,Bi-LSTM算法的应用进一步挖掘了边坡位移隐含的时间特征。现有位移预测方法虽然在不同方面取得了一定进展,但普遍存在对位移动态性挖掘不充分、模型参数选择方法粗糙和特征处理能力弱等问题。

鉴于此,笔者拟基于现有位移预测的不足,首先,通过时间序列分解模型,将尾矿坝位移分解为趋

势项位移和周期项位移;然后,采用高斯回归时间序列预测模型预测趋势项位移,利用Copula函数确立诱发因素与周期项位移间的整体相关性,并构建改进麻雀搜索算法(Multi strategy Improved Sparrow Search Algorithm, MISSA)-卷积神经网络(Convolutional Neural Networks, CNN)-BiLSTM模型,预测周期项位移;最后,叠加趋势项和周期项位移预测值,得到累积位移预测值,实现尾矿坝位移的动态预测,以期尾矿坝灾害预警提供决策依据。

1 方法与模型

1.1 时间序列分解模型

尾矿坝位移变化由坝体内部地质状况和外部诱因共同作用引起。在坝体的地质条件(如工程地貌、尾矿粒径)影响下,尾矿坝位移在较长时间尺度上通常呈现单调递增趋势;同时,在外部诱发因素(如季节性降雨、库水位升降等)作用下,其位移在较小时间尺度上呈现近似周期性特征。总位移可分解为:

$$S(t) = \phi(t) + \eta(t) \quad (1)$$

式中: t 为时间; $S(t)$ 为位移时间序列; $\phi(t)$ 为趋势项位移,由尾矿坝所处地质条件及坝体自身条件决定,反映位移长期变化趋势; $\eta(t)$ 为周期项位移,受降雨、库水位变化等外界诱发因素的控制。

1.2 Copula函数

根据Sklar定理,给定具有边缘分布 F_1 、 F_2 的联合分布函数 F ,存在一个Copula函数 C ,满足 $F(x_1, x_2) = C(F_1(x_1), F_2(x_2))$ 。由此可得联合分布密度函数:

$$f(x_1, x_2) = c(F_1(x_1), F_2(x_2))f_1(x_1)f_2(x_2) \quad (2)$$

式中: $c(F_1(x_1), F_2(x_2))$ 为Copula函数的密度函数; $f_1(x_1)$ 、 $f_2(x_2)$ 分别为边缘分布 F_1 、 F_2 的密度函数。

1.3 MISSA 优化算法

深度学习模型的预测性能受超参数选择影响甚大,采用优化算法(如麻雀搜索算法、哈里斯鹰算法等)选取参数是一种有效发挥模型拟合能力的方法。李雅丽等^[9]研究发现,麻雀搜索算法在多方面优于其他群优化算法,但在处理复杂函数时存在全局搜索性较差、容易陷入局部最优等缺点。因此,从算法搜索的不同阶段出发,提出一种多策略融合的 MISSA。具体改进策略如下:①引入切比雪夫混沌映射进行种群初始化^[10],从而获得一个具有较强全局搜索能力的初始种群。②采用动态自适应权重策略^[11],通过引入权重因子 ω ,结合上一步的全局最优解来调整发现者位置,有利于平衡全局开发与局部开发。③引入柯西变异策略^[12]提高种群迭代后期的多样性,从而提高算法的收敛精度。④利用精英反向学习策略^[13]扩大搜索范围提高全局最优解的发现概率。

1.4 CNN 模型

实际预测过程中,尾矿坝位移受多特征参数影响。为提高尾矿坝位移预测精度,采用一维 CNN 对数据进行特征处理。其一般结构主要包含输入层、卷积层、激活函数、池化层与输出层。在应用过程中,为避免池化过程导致信息丢失,去除 CNN 池化层。CNN 主要通过卷积核实现权值共享,充分挖掘输入变量的内在关系并关注显著特征。其具体原理公式为:

$$y(k) = h(k) \cdot u(k) = \sum_{i=0}^N h(k-i)u(i) \quad (3)$$

式中: y, h, u 为序列; k 为卷积次数; N 为 u 的长度; i 为从 $0 \sim N$ 的整数。

1.5 BiLSTM 模型

LSTM 作为深度学习算法的一种,在处理时间序列数据预测任务上具有优势^[14]。LSTM 算法以细胞状态的更新与短期记忆值的输出为主要任务,利用输入门、遗忘门为细胞状态的更新提供参数,通过输出门处理数据并输出短期记忆值,最终实现对输入信息重要程度的区分,并根据重要程度选择性保留和遗忘信息。

相较传统单向神经网络仅按时间序列前向传播的训练方式,BiLSTM 通过双向网络实现过去和未来隐藏层状态的递归反馈,从而更有效地发掘数据时序特征,提高模型预测精度和特征数据利用率。

1.6 组合模型搭建

结合 CNN 特征工程和 BiLSTM 时序处理优势,在 BiLSTM 隐藏层前加入卷积层。将水平位移和 6 个影响因子串联为向量输入模型输入层,之后进入卷积层进行特征提取并形成特征向量,最终将特征向量输入 BiLSTM,实现位移的动态预测。组合模型结构如图 1 所示。为充分发挥模型性能,采用 MISSA 优化算法调整深度学习模型参数,具体优化过程流程如下:①设置种群规模、最大迭代次数及参数寻优区间,并利用切比雪夫混沌映射初始化麻雀群体。②计算当前各个麻雀适应度并进行适应度排序,找出最优适应度值及对应位置。③从适应度值较优的麻雀中,选取部分麻雀为发现者,使用动态自适应权重更新麻雀位置,寻找最优解。④利用柯西变异和反向学习策略扰动当前最优解,产生新解。⑤根据麻雀当前状态,更新麻雀群体最优解。⑥重复步骤③—⑤,直到达到预定迭代次数或满足收敛条件。⑦输入寻优后参数搭建 CNN-BiLSTM 模型。

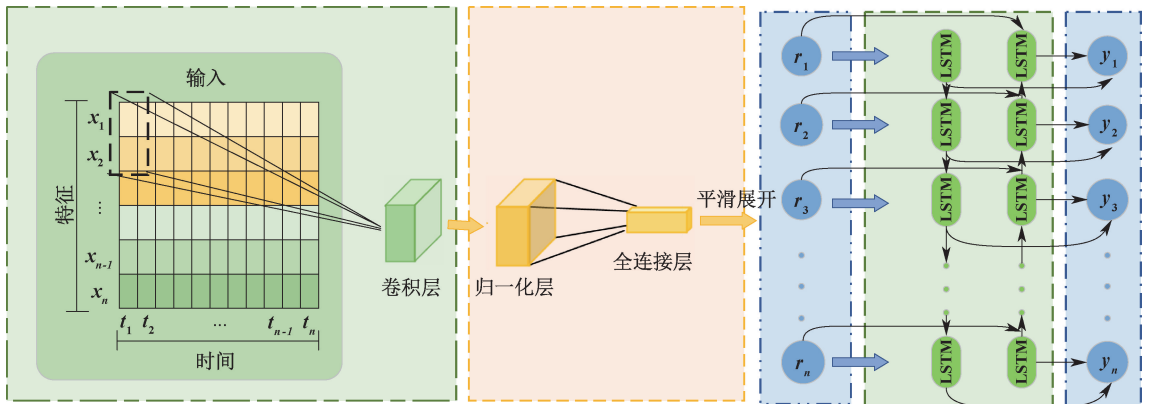


图 1 组合模型结构

Fig. 1 Schematic diagram of the combined model structure

1.7 模型精度评价

采用均方根误差 (Root Mean Square Error, RMSE) 和相关性系数 R 等指标评估尾矿坝位移模型预测精度^[15]。此外,绝对误差和相对误差也用于分析预测结果。RMSE 和 R 的计算式为:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - \hat{x}_i)^2}{F}} \quad (4)$$

$$R = \frac{\sum_{i=1}^N (x_i - \bar{x})(\hat{x}_i - \hat{\bar{x}})}{\sqrt{\sum_{i=1}^N (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^N (\hat{x}_i - \hat{\bar{x}})^2}} \quad (5)$$

式中: x_i, \hat{x}_i 分别为真实值和预测值; \bar{x} 和 $\hat{\bar{x}}$ 分别为真实值和预测值的平均值; F 为样本数。

2 尾矿库概况与高位移成因分析

2.1 尾矿库概况

该尾矿库位于陕西省略阳县红岩沟,库容 98 万 m^3 ,属于堆砌式尾矿库。尾矿库坝体上共有 10 个监测点,各监测点编号及具体监测位置如图 2 所示,其中,D 表示一级子坝及其附近监测点,G 表示初期坝与堆积坝交界处的两侧监测点,Z 表示交界处中心监测点,J 和 P 表示交界处附近监测点。为全面反映坝体变形情况,选择初期坝与堆积坝交界区域中心 Z1 监测点详细分析。

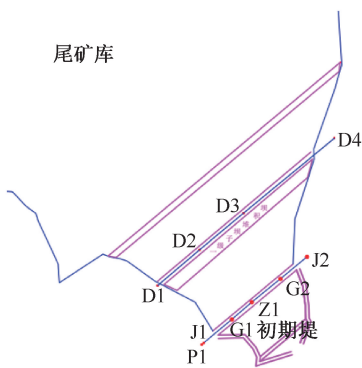


图 2 尾矿库主坝坝体监测平面布置

Fig. 2 Monitoring plan of the main dam of the tailings pond

2.2 尾矿坝高位移成因分析

尾矿库滑坡是典型的推移式滑坡,其滑动力主要来自澄清池水对尾矿坝的浸润作用,导致尾矿坝内部孔隙水压力与外部静水压力增大,推动坡体下滑^[16]并引发前部隆起、开裂变形。

为研究尾矿库随时间的动态演变过程,选取 10 年,以月为单位的监测数据,包括累计位移、库水位及降雨量,监测曲线如图 3、图 4 所示。根据尾矿坝演化情况,将演化过程分为先后 3 个阶段:初期不稳定阶段 A,中期稳定性适应阶段 B,后期稳定性增强阶段 C。将监测曲线分 3 个阶段分析,并单独研究位移陡增点,探讨其出现的主要原因。

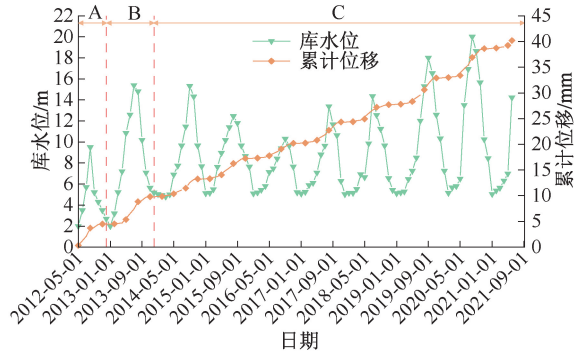


图 3 累计位移-库水位监测数据

Fig. 3 Cumulative displacement-reservoir water level monitoring data graph




图 4 累计位移-降雨量监测数据

Fig. 4 Cumulative displacement-rainfall monitoring data graph

根据图 3、图 4 显示,在初期阶段,库水位整体较低,高位移主要受降雨驱动,尾矿处于矿浆向固结演化过程中^[17],最大位移受降雨和初期演化状态共同影响;在中期阶段,库水位整体升高,库水位对尾矿坝的影响程度逐渐增强,尾矿坝位移极大值受库水位抬升影响较大;在后期阶段,库水位周期性波动,尾矿坝适应了库水位的变化,位移进入稳定状态,尾矿坝位移主要受降雨量与库水位影响。

在尾矿库服役期间,尾矿坝累计位移量持续增加,其中,由于尾矿排放初期含水率较大以及库水位的突然抬升,大大降低了尾矿内部的基质吸力与抗剪强度,使得尾矿坝变形速率达到最大,随后进入稳定变形阶段。

3 尾矿坝位移预测

3.1 趋势项位移提取及预测

趋势项位移反映了尾矿坝位移的长期变化趋势,采用移动平均法提取趋势项位移。设 $S_i = \{s_1, s_2, \dots, s_i\}$ 为原始位移时间序列,则趋势项位移的计算方法如下:

$$\phi(r) = \frac{s_r + s_{r-1} + \dots + s_{r-l+1}}{l} \quad (r = l, l + 1, \dots, t) \quad (6)$$

式中: l 为周期值; r 为从 $l \sim t$ 的正整数; $\phi(r)$ 为趋势项位移, l 的选取对于趋势项的提取结果至关重要,较小的 l 值会导致平均值更加敏感,容易受到噪声和突发波动的影响;较大的 l 值会导致平滑后的数据序列变化较为缓慢,反映当前数据的变化相对滞后。鉴于库水位以年为单位呈现周期性变化, l 取 12。趋势项位移提取值如图 5 所示。




图 5 趋势项位移提取值

Fig. 5 Trend item displacement extracts values

采用高斯回归时间序列预测模型,通过高斯过程结合时间特征对趋势项位移进行时间序列建模与预测,其表达式为:

$$V = K(E, Q) K(Q, Q)^{-1} y \quad (7)$$

式中: K 为协方差函数; E 为新的输入; Q 为输入向量; y 为目标输出; V 为预测目标。

利用高斯回归时间序列预测模型预测趋势项位移,并传统多项式拟合预测法比较,结果分别如图 6 与图 7 所示。由图 6、图 7 可知:高斯回归时间序列预测模型预测结果 R 为 0.998, RMSE 为 0.10 mm,多项式拟合模型预测结果 R 为 0.990, RMSE 为 0.58 mm,相较于多项式拟合预测,高斯回归时间序列预测模型可更好地预测趋势项位移变化。




图 6 高斯回归趋势项位移预测结果

Fig. 6 Gaussian regression trend term displacement prediction results




图 7 多项式函数趋势项位移预测结果

Fig. 7 Polynomial function trend term displacement prediction results

3.2 周期项位移提取与预测

3.2.1 周期项位移提取

从尾矿坝累积位移中剔除趋势项位移,得到周期项位移,如图 8 所示。

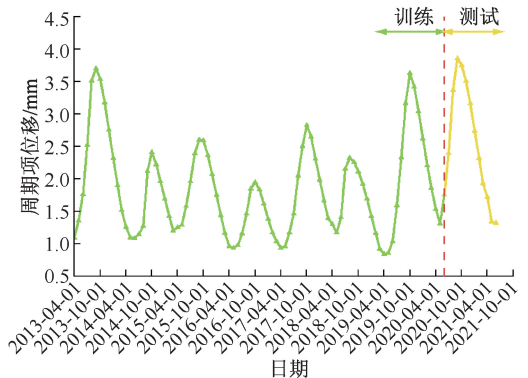


图 8 周期项位移提取结果

Fig. 8 Periodic term displacement extraction results

3.2.2 影响因子选取

影响因子的选取对位移预测精度的好坏至关重要。尾矿坝累积位移-时间曲线呈阶跃型,根据 2.2 节的分析,降雨及周期性水库水位波动是导致该变形特征的主导因素。此外,尾矿库所处的不同时间演

化阶段对于外界诱发因素下尾矿坝位移的精确预测也有着重要影响。

1) 降雨。降雨对尾矿坝位移影响主要有 2 方面:①冲刷作用改变表面结构^[18];②雨水入渗切割土体。入渗过程中,孔隙水压力增大导致颗粒间摩擦力和黏结力减小,导致土体结构松散易移动,增强了土体的不稳定性。考虑到降雨量入渗是一个相对缓慢的过程,图 9 为周期项位移分别与当月、前一个月降雨量的变化情况。图 9 显示,监测点处周期项位移波动规律与当前降雨量及前一个月降雨量较为一致,因此,选择当月降雨量与前一个月降雨量作为影响因素。




图 9 周期项位移-降雨量关系

Fig. 9 Schematic diagram of periodic term displacement-rainfall

2) 库水位。库水位对尾矿坝位移的影响主要是通过库水位在渗透过程中产生的水力耦合作用。在吸附力和毛细力^[19]共同作用下,尾矿坝中后部的饱和尾矿体积逐渐增大,导致泥质成分不断积累。这一现象增强了尾矿坝内部的水压力和重力,从而降低尾矿坝的有效应力。此外,在干湿循环过程中,尾矿坝内部土体框架会逐渐变得松散,可能导致内部裂缝或破坏产生^[20]。库水位同样由于入渗过程的缓慢性导致其对于位移的影响产生了一定的滞后效应。图 10 为周期项位移分别与当月、前一个月库水位高程的变化情况,图 10 显示,其当月和前一个月库水位高程的变化趋势与周期项位移相同,因此,选择当月与前一个月库水位高程作为影响因素。

3) 尾矿坝变形形态。在相同影响因素下,不同阶段的、尾矿坝变形情况存在显著差异。当尾矿坝处于稳定状态时,即使经历较强降雨量,位移量也不会很大。相反,当尾矿坝处于不稳定状态时,即使遭遇普通降雨,也可能引发尾矿坝溃坝。因此,选择尾矿坝当月与前一个月的位移量,以表示其当前所处的稳定状态。周期项位移与位移增量关系如图 11 所示。




图 10 周期项位移-库水位高程关系示意

Fig. 10 Schematic diagram of periodic term displacement-reservoir water level elevation




图 11 周期项位移-位移增量关系

Fig. 11 Schematic diagram of periodic term displacement-displacement increments

为验证所选取的影响因子对周期位移的影响,选取合适的 Copula 函数,利用其 Pearson 系数表示相关变量的关联性,通过分析上下尾厚度厘清影响因素对尾矿坝位移的影响,采用 Gaussian, Student's t 型, Gumbel, Clayton, Frank 等 5 种 Copula 函数进行耦合关系描述,其中, Gaussian 与 Student's t 型 Copula 函数分别通过标准正态分布与 t 分布的累计分布函数来转换边缘分布建立多维变量之间的相关性,这类函数均有对称的尾部相关性; Gumbel、Clayton、Frank 型 Copula 函数则根据不同的生成元函数得到相应的阿基米德 Copula 函数,分别适合上尾部厚尾特征明显、下尾部厚尾特征明显与对称厚尾结构变量耦合关系的描述。

同时,利用欧氏距离可衡量多维随机变量之间相似度的特性,通过比较不同因素与周期项位移在各函数下的欧氏距离,选择最能捕捉不同变量间依赖关系的 Copula 函数。欧氏距离越小,函数对实际数据的相关性结构拟合效果越好。表 1 为各影响因素在不同 Copula 函数条件下对周期性位移的欧氏距离。

表 2 为各影响因素在合适的 Copula 函数条件下

得到的与周期性位移的 Pearson 相关系数。各个影响因素与周期项位移 Copula 函数密度如图 12 所示。

表 1 不同 Copula 函数欧氏距离

Table 1 Copula function euclidean distance

Copula 函数	当月库水位	上月库水位	当月降雨量	上月降雨量	上月位移增量	当月位移增量
Gaussian	0.02	0.10	0.04	0.04	0.02	0.03
Student's t	0.04	0.07	0.21	0.08	0.04	0.08
Gumbel	0.01	0.02	0.03	0.20	0.18	0.01
Clayton	0.09	0.03	0.10	0.12	0.05	0.12
Frank	0.02	0.01	0.04	0.03	0.01	0.03

表 2 周期项位移与影响因素 Pearson 相关系数

Table 2 Table of periodic term displacement and influencing factors Pearson correlation coefficient

当月库水位	上月库水位	当月降雨量	上月降雨量	上月位移增量	当月位移增量
0.84	0.77	0.78	0.81	0.80	0.79

图 12 显示,当前月库水位、降雨量和位移增量与周期项位移关系可用 Gumbel-copula 函数描述,其上尾部厚尾特性较为敏感,下尾部厚尾特性较弱,呈 J 型曲线,上下尾部渐进关联,上尾部关联强度较高。表明尾矿坝位移在高或低时,3 个影响因素与周期项位移均呈显著强相关性,高位移时相关性更强。前一个月库水位、降雨量和位移增量与周期项位移关系可用 Frank-copula 函数描述,其具有对称厚尾,呈 C 型曲线,上下尾部强度相似。由于前一个月影响因素会影响下个月土壤初始含水率及土体结构,因此,这些因素对下月尾矿坝高低位移均具有强相关性。经上述 Copula 函数结果分析验证,所选取的影响因子与尾矿坝周期项位移关系显著,可采用这 6 个影响因子预测周期项位移。

3.2.3 模型建立与参数选取

首先,归一化处理数据并将数据分为训练集和测试集。将 6 个影响因子作为输入,周期位移为输出。使用 Matlab2022 搭建多算法耦合模型,设定深度学习模型依次为输入层、折叠层、2 次卷积层、展开层、平滑层、2 层 BiLSTM 与 Dropout 交替层、全连接层及输出层;优化算法设定种群数量为 20,最大迭代次数为 50,并分别设立 6 个参数的下边界为 [5,100,0.000 01,0.001,0.001,0.000 001];上边界为 [100,500,0.1,2,1,1],将损失函数设为适应度函数,通过参数调整,训练深度学习模型,使损失函数数值达到最小,参数训练结果见表 3。将得到的最优参数用于构建深度学习模型,并利用构建的深度学习模型进行预测。

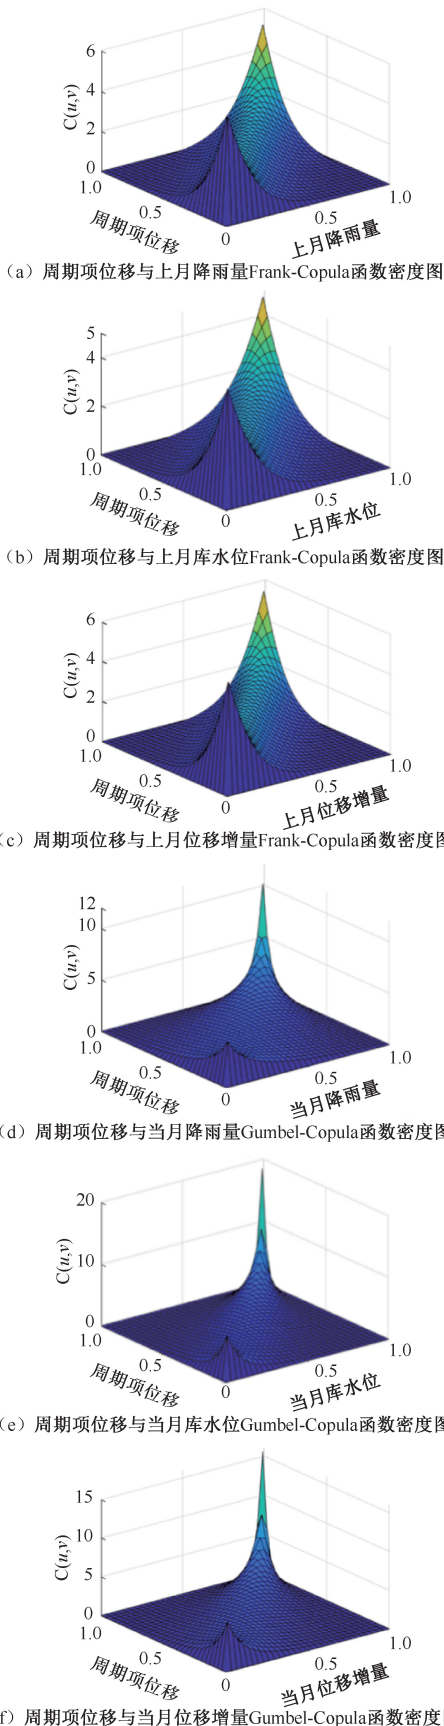


图 12 Copula 函数密度

Fig. 12 Copula function density diagram

表3 MISSA 优化 CNN-BiLSTM 参数结果

Table 3 MISSA optimization of CNN-BiLSTM parameters

训练所 选取样 本数量	最大训 练周 期数	初始学 习率	梯度 阈值	学习率 衰减 因子	正则化 系数
24	100	0.01	1	0.1	0.001

3.2.4 周期项预测结果对比分析

为验证本文方法的有效性,选取非线性预测能力较强的 SVR 模型与未经特征处理的 BiLSTM 进行预测效果对比。为避免模型参数选取方法差异导致的结果误差,同样用 MISSA 优化算法选取 SVR 与 BiLSTM 模型参数。基于尾矿库多处于中后期的现状,将 2020 年 7 月—2021 年 6 月的位移量作为预测目标。

周期项位移预测结果显示,MISSA-CNN-BiLSTM 预测结果的相关性系数 R 为 0.995, RMSE 为 0.094 9 mm,整体预测精度较高。具体预测结果如图 13 和表 4 所示。

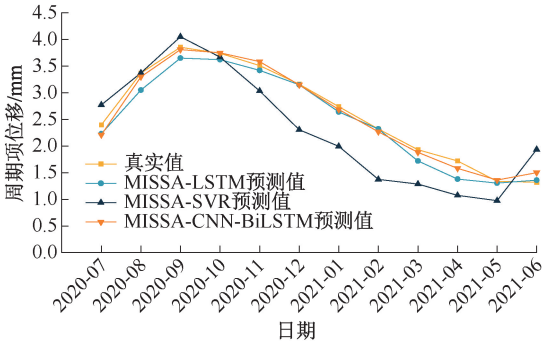


图 13 预测结果对比

Fig. 13 Prediction result graph

表 4 周期项位移预测精度及误差对比

Table 4 Periodic term displacement prediction accuracy and error comparison mm

日期	实际 值	MISSA- BiLSTM		MISSA-CNN- BiLSTM		MISSA-SVR	
		预测 值	误差 值	预测 值	误差 值	预测 值	误差 值
2020-07	2.40	2.23	0.17	2.21	0.19	2.77	0.38
2020-08	3.37	3.05	0.32	3.30	0.07	3.37	0.00
2020-09	3.85	3.65	0.20	3.81	0.04	4.05	0.20
2020-10	3.74	3.62	0.12	3.75	0.01	3.67	0.07
2020-11	3.51	3.42	0.09	3.59	0.08	3.03	0.48
2020-12	3.16	3.15	0.01	3.15	0.01	2.31	0.85

续表 4

日期	实际 值	MISSA- BiLSTM		MISSA-CNN- BiLSTM		MISSA-SVR	
		预测 值	误差 值	预测 值	误差 值	预测 值	误差 值
2021-01	2.74	2.64	0.10	2.69	0.05	2.00	0.74
2021-02	2.32	2.32	0.00	2.27	0.05	1.38	0.94
2021-03	1.93	1.72	0.21	1.88	0.05	1.29	0.64
2021-04	1.72	1.38	0.34	1.58	0.14	1.07	0.65
2021-05	1.34	1.31	0.03	1.36	0.02	0.98	0.36
2021-06	1.32	1.36	0.04	1.50	0.18	1.94	0.62
平均值	—	—	0.14	—	0.07	—	0.49
RMSE	—	—	0.18	—	0.09	—	0.57
R	—	—	0.984	—	0.995	—	0.874

在尾矿坝位移上升的 7—9 月期间,依托 MISSA-BiLSTM 类算法在首月预测精度相近,但随周期项位移增大,差异逐渐显现。融合了特征处理 CNN 的模型能更有效挖掘不同影响因子对高位移影响,其在 3 mm 以上位移预测表现较 MISSA-BiLSTM 模型优越,较低位移时,2 模型预测精度相近;由于 SVR 模型在预测过程中不考虑之前各影响因素的情况,仅依托当前影响因素进行预测,使得其相邻预测结果之间变化较大,位移上升过程中预测结果上升太快整体预测值偏高,下降过程中下降太快预测值偏低,整体预测精度较低。由于尾矿坝安全预报关键在于高风险位移的预测与分析,MISSA-CNN-BiLSTM 更适用于尾矿坝的实际情况与位移预测。

3.3 尾矿坝累积位移预测

根据时间序列分解原理,将高斯回归趋势项位移预测值与 MISSA-CNN-BiLSTM 周期项位移预测值叠加,即可得到尾矿坝累积位移预测值,具体预测结果如图 14 和表 5 所示。图 14 与表 5 预测结果表明:尾矿坝累积位移预测值与实测值基本一致,相关性系数 R 为 0.996,均方根误差 RMSE 为 0.13 mm,总体预测精度较高且能较好地预测出尾矿坝位移阶跃型变化。

4 结 论

1) 利用高斯回归结合趋势位移进行时间序列建模,能够更有效地挖掘趋势项位移的时间动态趋




图 14 累计位移预测结果及误差

Fig. 14 Cumulative displacement prediction results and error plot

势,进一步提高趋势项位移的预测精度。

2) 结合 BiLSTM 时间序列处理优势与 CNN 特征挖掘学习能力,能有效提高模型对高位移的耦合能力,使得模型对高位移的变化更加敏感,更有利于尾矿坝风险决策,同时,利用 MISSA 算法选取模型参数,可充分发挥模型的拟合能力。

3) 通过将高斯回归趋势项位移预测值与 MISSA-CNN-BiLSTM 周期项位移预测值叠加,得到的最终累计位移预测值与实测值基本一致,预测结

表 5 累计位移预测精度及误差

Table 5 Cumulative displacement prediction accuracy and error mm

日期	实际值	预测值	误差值
2020-07	35.43	35.29	0.14
2020-08	36.93	36.72	0.21
2020-09	37.92	37.89	0.03
2020-10	38.29	38.42	0.14
2020-11	38.53	38.79	0.25
2020-12	38.66	38.76	0.10
2021-01	38.71	38.71	0.00
2021-02	38.77	38.85	0.08
2021-03	38.85	38.92	0.07
2021-04	39.12	39.00	0.13
2021-05	39.23	39.27	0.04
2021-06	39.70	39.80	0.10

果相关性系数为 0.996,均方根误差为 0.13 mm。表明文中建立的 MISSA-CNN-BiLSTM 多算法耦合模型预测精度较高,且能较好地预测出尾矿坝位移的阶跃型变化。

4) 由于尾矿坝位移的动态变化受多种因素影响,因素的选择和数量对提高模型精度具有显著影响。在后续研究中,将进一步深入探索尾矿坝位移影响因素。

参 考 文 献

[1] LIU Zhongqiang, GUO Dong, LACASSE S, et al. Algorithms for intelligent prediction of landslide displacements [J]. Journal of Zhejiang University-Science A: Applied Physics & Engineering, 2020, 21(6): 412-429.

[2] ZHAI Qian, RAHARDJO H, SATYANAGA A, et al. Effect of the uncertainty in soil-water characteristic curve on the estimated shear strength of unsaturated soil [J]. Journal of Zhejiang University-Science A: Applied Physics & Engineering, 2020, 21(4): 317-330.

[3] 冯文凯, 易小宇, 孟睿, 等. 三峡库区木鱼包滑坡不同库水升降速率变形响应离心模型试验研究[J]. 水利学报, 2021, 52(5): 578-588.
FENG Wenkai, YI Xiaoyu, MENG Rui, et al. Study on deformation response of Muyubao landslide in Three Gorges region under different water fluctuation rates by centrifugal model test [J]. Journal of Hydraulic Engineering, 2021, 52(5): 578-588.

[4] 刘迪, 卢才武, 连民杰, 等. 基于贝叶斯决策的尾矿坝干滩长度预警研究[J]. 中国安全科学学报, 2022, 32(增 1): 120-126.
LIU Di, LU Caiwu, LIAN Minjie, et al. Dry beach length pre-warning of tailings dam based on Bayesian decision [J]. China Safety Science Journal, 2022, 32(S1): 120-126.

[5] 王晨辉, 赵贻玟, 郭伟, 等. 滑坡位移 EEMD-SVR 预测模型[J]. 测绘学报, 2022, 51(10): 2 196-2 204.
WANG Chenhui, ZHAO Yijiu, GUO Wei, et al. Displacement prediction model of landslide based on ensemble empirical mode decomposition and support vector regression [J]. Journal of Geodesy and Geoinformation Science, 2022, 51(10): 2 196-2 204.

[6] 高雅萍, 陈曦, 涂锐. 顾及降雨影响的动态优化时滞时序 GM(1,2) 模型在滑坡位移预测中的应用[J]. 测绘学报, 2022, 51(10): 2 183-2 195.
GAO Yaping, CHEN Xi, TU Rui. Application of dynamic optimization time delay GM(1,2) model in landslide displacement prediction considering the influence of rainfall [J]. Journal of Geodesy and Geoinformation Science, 2022, 51(10): 2 183-2 195.

[7] 张振坤, 张冬梅, 李江, 等. 基于多头自注意力机制的 LSTM-MH-SA 滑坡位移预测模型研究[J]. 岩土力学,

- 2022, 43(增2): 477-486,507.
- ZHANG Zhenkun, ZHANG Dongmei, LI Jiang, et al. LSTM-MH-SA landslide displacement prediction model based on multi-head self-attention mechanism [J]. *Rock and Soil Mechanics*, 2022, 43(S2): 477-486,507.
- [8] 唐菲菲, 唐天俊, 朱洪洲, 等. 结合注意力机制和 Bi-LSTM 的降雨型滑坡位移预测[J]. *测绘通报*, 2022(9): 74-79.
- TANG Feifei, TANG Tianjun, ZHU Hongzhou, et al. Rainfall-landslide deformation prediction based on attention mechanism and Bi-LSTM [J]. *Bulletin of Surveying and Mapping*, 2022(9): 74-79.
- [9] 李雅丽, 王淑琴, 陈倩茹, 等. 若干新型群智能优化算法的对比研究[J]. *计算机工程与应用*, 2020, 56(22): 1-12.
- LI Yali, WANG Shuqin, CHEN Qianru, et al. Comparative study of several new swarm intelligence optimization algorithms [J]. *Computer Engineering and Applications*, 2020, 56(22): 1-12.
- [10] TANG Andi, ZHOU Huan, HAN Tong, et al. A chaos sparrow search algorithm with logarithmic spiral and adaptive step for engineering problems [J]. *Computer Modeling in Engineering & Sciences* 2022, 130(1): 331-364.
- [11] OUYANG Chengtia, QIU Yaxian, ZHU Dongli. Adaptive spiral flying sparrow search algorithm [J]. *Scientific Programming*, 2021, 7; DOI:10.1155/2021/6505253.
- [12] 毛清华, 张强. 融合柯西变异和反向学习的改进麻雀算法[J]. *计算机科学与探索*, 2021, 15(6): 1155-1164.
- MAO Qinghua, ZHANG Qiang. Improved sparrow algorithm combining cauchy mutation and opposition-based learning [J]. *Journal of Frontiers of Computer Science and Technology*, 2021, 15(6): 1155-1164.
- [13] 张琳, 汪廷华, 周慧颖. 一种多策略改进的麻雀搜索算法[J]. *计算机工程与应用*, 2022, 58(11): 133-140.
- ZHANG Lin, WANG Tinghua, ZHOU Huiying. Multi-strategy improved sparrow search algorithm [J]. *Computer Engineering and Applications*, 2022, 58(11): 133-140.
- [14] 戴健非, 杨鹏, 诸利一, 等. 集成 PCA 和 LSTM 神经网络的浸润线预测方法[J]. *中国安全科学学报*, 2020, 30(3): 94-101.
- DAI Jianfei, YANG Peng, ZHU Liyi, et al. A PCA-LSTM neural network-integrated method for phreatic line prediction [J]. *China Safety Science Journal*, 2020, 30(3): 94-101.
- [15] MA Junwei, XIA Ding, GUO Haixiang, et al. Metaheuristic-based support vector regression for landslide displacement prediction: a comparative study [J]. *Landslides*, 2022, 19(10): 2489-2511.
- [16] 武立功, 肖利兴, 刘晓峰, 等. 尾砂粒径对尾矿坝漫顶溃坝的影响[J]. *中国安全科学学报*, 2020, 30(4): 160-165.
- WU Ligong, XIAO Lixing, LIU Xiaofeng, et al. Influence of particle size on overtopping dam break of tailings dam [J]. *China Safety Science Journal*, 2020, 30(4): 160-165.
- [17] ISLAM S, WILLIAMS D J, LLANO M, et al. Settling, consolidation and shear strength behaviour of coal tailings slurry [J]. *International Journal of Mining Science and Technology*, 2020, 30(6): 108-116.
- [18] WANG Yixuan, CHAI Junrui, CAO Jing, et al. Effects of seepage on a three-layered slope and its stability analysis under rainfall conditions [J]. *Natural Hazards*, 2020, 102: 1269-1278.
- [19] 刘迪, 卢才武, 连民杰, 等. 基于粒径效应影响的尾矿毛细特性试验[J]. *中国有色金属学报*, 2020, 30(11): 2746-2757.
- LIU Di, LU Caiwu, LIAN Minjie, et al. Experiment on tailings capillary characteristics based on particle size effect [J]. *Transactions of Nonferrous Metals Society of China*, 2020, 30(11): 2746-2757.
- [20] 罗小峰, 侯运炳, 闫浩东, 等. 干湿循环作用下全尾砂固结体的损伤机理[J]. *中国有色金属学报*, 2021, 31(12): 3730-3739.
- LUO Xiaofeng, HOU Yunbing, YAN Haodong, et al. Damage mechanism of total tailings consolidation under action of dry-wet cycle [J]. *Transactions of Nonferrous Metals Society of China*, 2021, 31(12): 3730-3739.

作者简介: 刘迪 (1987—), 女, 陕西咸阳人, 博士, 主要从事智慧矿山、尾矿坝安全及毛细水作用等方面的研究。E-mail: safety_ld2010@126.com。

